

DOI:10.20033/j.1003-7241.(2026)06-0072-05

双碳背景下结合 Informer 和 IPOA 算法的电力负荷预测

薛万磊¹, 李校莹¹, 牛华忠¹, 牟颖¹, 汲国强²

(1. 国网山东省电力公司 经济技术研究院, 济南 250021; 2. 国网能源研究院有限公司, 北京 102209)

摘要:在双碳目标背景下,准确预测电力负荷对于实现能源优化和电网稳定运行至关重要,提出了一种结合 I 时间序列预测模型和改进鹈鹕优化算法的电力负荷预测模型。首先对原始数据进行清洗和标准化处理,通过改进鹈鹕优化算法优化时间序列预测模型的超参数。引入的时间失真指数提高对时间序列形状和时间扭曲的捕捉能力。为验证所提模型的有效性,将该模型与标准鹈鹕优化算法等开展了对比测试,并在标准测试函数和实际电力负荷数据集上对误差和拟合优度进行了全面评估。实验结果显示,提出的改进模型预测误差范围从标准鹈鹕优化算法模型的 $-7.5 \sim 5.8 \text{ kW}\cdot\text{h}$ 显著降低至 $-4.3 \sim 4.3 \text{ kW}\cdot\text{h}$,决定系数值提高了 $2.53\% \sim 6.6\%$ 。该结果验证了模型在提高预测精度和稳定性方面的显著效果,对双碳目标下优化电力资源配置具有重要的理论和实践意义。

关键词:双碳目标;电力负荷;预测;Informer;IPOA 算法;机器学习

中图分类号: TP18;TN715

文献标志码: A

文章编号: 1003-7241(2026)06-0072-05

Combining Informer and IPOA algorithms for power load forecasting under the dual carbon background

Xue Wanlei¹, Li Xiaoying¹, Niu Huazhong¹, Mou Ying¹, Ji Guoqiang²

(1. Economic & Technology Research Institute, State Grid Shandong Electric Power Company, Jinan 250021, China;

2. State Grid Energy Research Institute Co., Ltd., Beijing 102209, China)

Abstract: Accurately predicting power load is crucial for achieving energy optimization and stable operation of the power grid in the context of the dual carbon target. This article proposes a power load forecasting model that combines an I time series forecasting model with an improved Pelican optimization algorithm. This article first cleans and standardizes the raw data, and optimizes the hyperparameters of the time series prediction model by improving the Pelican optimization algorithm. The introduced time distortion index improves the ability to capture the shape and time distortion of time series. To verify the effectiveness of the proposed model, this paper conducted comparative tests with standard Pelican optimization algorithms, and comprehensively evaluated the error and goodness of fit on standard test functions and actual power load datasets. The experimental results show that the improved model proposed in this paper significantly reduces the prediction error range from $-7.5 \text{ kW}\cdot\text{h}$ to $5.8 \text{ kW}\cdot\text{h}$ of the standard Pelican optimization algorithm model to $-4.3 \text{ kW}\cdot\text{h}$ to $4.3 \text{ kW}\cdot\text{h}$, and increases the determination coefficient value by 2.53% to 6.6% . This result validates the significant effect of the model in improving prediction accuracy and stability, and has important theoretical and practical significance for optimizing power resource allocation under the dual carbon target.

Keywords: dual carbon targets; power load; forecasting; Informer; IPOA algorithm; machine learning

随着全球气候变化对生态环境的影响日益加剧,实现碳达峰和碳中和的双碳目标已成为国际社会的共同责任。在此背景下,能源转型和电力系统的优化运行显得尤为重要^[1]。电力负荷预测作为电力系统规划和运行管理的关键环节,其准确性直接关系到电网的稳定性和能源的高效分配^[2-3]。肖威等学者针对电力负荷数据的强非线性和非平稳性特点,提出一种混合预测模型。将各预测结果重构以获得电力负荷的预测值。仿真结果证实,该混合模型在提取模态特征和预测精度方面均优于现有方法^[4]。为了提高空间电力负荷预测的准确性。Yadav 等^[5]研究了

基于高斯过程回归(gaussian process regression, GPR)的电力负荷预测方法,通过训练十二个 GPR 模型,并使用不同的核函数评估预测效果,结果显示“指数”核函数模型在负荷预测中 MAPE 最低,验证了模型的优越性。然而,传统的电力负荷预测方法,包括经典的统计方法和一些机器学习技术,往往在处理长序列依赖和非线性特征时表现不足,难以满足当前对高精度预测的需求^[6-7]。此外,随着可再生能源的大规模并网和电力需求的快速增长,电力系统的不确定性和动态性显著增加,这对负荷预测的精度和鲁棒性提出了更高的要求^[8-9]。现有方法在模型泛化

收稿日期:2024-12-23;录用日期:2025-01-28

基金项目:国网山东省电力科技项目资助(520625220001)

作者简介:薛万磊(1978—),男,硕士,正高级工程师,研究方向:能源经济、电力供需预测技术。

引用本文:薛万磊,李校莹,牛华忠,等.双碳背景下结合 Informer 和 IPOA 算法的电力负荷预测[J].自动化技术与应用,2026,45(6):72-76.(Xue Wanlei, Li Xiaoying, Niu Huazhong, et al. Combining Informer and IPOA algorithms for power load forecasting under the dual carbon background[J]. Techniques of Automation and Applications, 2026, 45(6): 72-76.)

能力和参数调优方面也存在局限,导致在实际应用中难以达到理想的预测效果^[10-11]。因此,针对传统方法的不足,提出了一种结合 Informer 算法和改进鹈鹕优化算法(improved pelican optimization algorithm, IPOA)的新型电力负荷预测模型,采用数据清洗和标准化处理方法对原始数据进行预处理,确保了数据质量的可靠性。研究的创新点在于,不仅利用了时间序列预测模型(Informer)在处理长序列时间依赖性方面的优势,还通过 IPOA 算法对模型参数进行了精细优化,以提高预测精度。通过这一创新性的研究,研究期望为电力系统在双碳目标下的优化运行提供强有力的决策支持。

1 负荷预测模型及优化策略

1.1 IPOA 算法在优化问题中的应用

受鹈鹕群体捕食行为启发,鹈鹕优化算法(pelican optimization algorithm, POA)被设计为一种群体智能优化工具,用于解决电力负荷预测问题^[12]。在 POA 中,算法个体象征鹈鹕,每个体的位置对应于解空间中的潜在解。通过模拟鹈鹕的飞行和捕食行为,算法执行种群初始化、适应度评估、位置更新和信息共享,以实现最优负荷预测模型参数的高效搜索,具体如式(1)所示。

$$x_{i,j} = l_j + \text{rand} \cdot (u_j - l_j), i = 1, 2, \dots, N, j = 1, 2, \dots, m \quad (1)$$

式中, $x_{i,j}$ 表示在第 j 个特征维度上,第 i 个优化算法中的个体所占据的值; N 代表群体中个体的总数; m 表示优化问题中涉及的独立变量的总数; rand 指的是一个在闭区间 $[0, 1]$ 内均匀分布的随机变量; l_j 定义为优化问题中第 j 个变量的最小可能值界限; u_j 表示优化问题中第 j 个决策变量的最大允许值。在 POA 框架内,种群成员即鹈鹕个体的状态通过所谓的种群矩阵来表示。该矩阵的结构设计中,每一行对应于一个候选解,而每一列则对应于优化问题中的一个变量,其值域为变量的建议取值。在这个矩阵中, \mathbf{X} 表示整个种群的状态集合,而 \mathbf{X}_i 特指第 i 个个体在解空间中的位置,如式(2)所示。

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \vdots \\ \mathbf{X}_i \\ \vdots \\ \mathbf{X}_N \end{bmatrix} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,j} & \cdots & x_{1,m} \\ \vdots & \ddots & \vdots & & \vdots \\ x_{i,1} & \cdots & x_{i,j} & \cdots & x_{i,m} \\ \vdots & & \vdots & \ddots & \vdots \\ x_{N,1} & \cdots & x_{N,j} & \cdots & x_{N,m} \end{bmatrix}_{N \times m} \quad (2)$$

在鹈鹕优化算法中,每个种群成员代表一个潜在的解决方案,即一只鹈鹕。这些解决方案的适应性通过目标函数进行评估,该函数量化了每个候选解的性能。目标函数的评估结果汇总在目标函数向量 \mathbf{F} 中,其中 F_i 代表第 i 个解决方案的目标函数值,如式(3)所示。

$$\mathbf{F} = \begin{bmatrix} F_1 \\ \vdots \\ F_i \\ \vdots \\ F_N \end{bmatrix}_{N \times 1} = \begin{bmatrix} F(\mathbf{X}_1) \\ \vdots \\ F(\mathbf{X}_i) \\ \vdots \\ F(\mathbf{X}_N) \end{bmatrix}_{N \times 1} \quad (3)$$

POA 模仿鹈鹕的捕食行为,分为探索和捕食两个阶段更新解。探索阶段,算法模拟鹈鹕广泛搜寻猎物,扩大搜索范围;捕食阶段则模拟集中捕食,精确定位最优解。在探索阶段,通过模拟鹈鹕定位并接近猎物的行为来优化搜索策略。猎物位置的随机生成为算法提供了在精确搜索问题上的增强勘探性,如式(4)所示。

$$x_{i,j}^{p_1} = \begin{cases} x_{i,j} + \text{rand} \cdot (p_j - I \cdot x_{i,j}), & F_p < F_i \\ x_{i,j} + \text{rand} \cdot (I \cdot x_{i,j} - p_j), & \text{其他} \end{cases} \quad (4)$$

式中, $x_{i,j}^{p_1}$ 为对于 POA 算法的第一阶段之后,更新第 i 个个体在第 j 个维度上的解空间坐标; I 是一个随机变量,其取值限定在集合 $[1, 2]$ 中; p_j 代表在目标维度上模拟猎物的具体坐标; F_p 为对应猎物位置的目标函数评估值。在 POA 中,当个体迁移至新位置且该位置的目标函数值表现更佳时,该新位置被采纳,如式(5)所示。

$$\mathbf{X}_i = \begin{cases} \mathbf{X}_i^{p_1}, & F_i^{p_1} < F_i \\ \mathbf{X}_i, & \text{其他} \end{cases} \quad (5)$$

式中, $\mathbf{X}_i^{p_1}$ 表示迭代中第 i 个个体的更新后的位置状态; $F_i^{p_1}$ 指的是在第 1 阶段结束时,针对第 i 个个体所评估的目标函数得分。在 POA 算法的捕食阶段,模拟鹈鹕捕猎行为的策略,即鹈鹕在水面展开翅膀并收集猎物至喉囊的动作,有助于算法在局部区域内进行细致搜索,从而增强其精确定位最优解的能力。通过数学模型,该策略被设计为评估并更新鹈鹕在解空间中邻近位置的适应度,以实现更优的解,如式(6)所示。

$$x_{i,j}^{p_2} = x_{i,j} + R \left(1 - \frac{t}{T} \right) \cdot (2 \cdot \text{rand} - 1) \cdot x_{i,j} \quad (6)$$

式中, $x_{i,j}^{p_2}$ 在第 2 阶段更新之后,第 i 个个体在第 j 个维度的解向量位置; R 为 0 或 2 的随机整数; t 表示当前的迭代轮数,而 T 定义了迭代过程的最大轮数限制; $R \left(1 - \frac{t}{T} \right)$ 定义了群体中每个成员的搜索范围,该范围用于围绕成员进行详尽的局部探索,目的是寻找并逼近更优质的解。根据以上优化,POA 优化流程如图 1 所示。

1.2 改进模型的构建与优化

为提升电力负荷预测的效率,在 POA 算法设计完成后,进一步引入了 Informer 模型,利用其自注意力机制,为长序列时间序列分析提供了一种高效的解决方案^[13]。该机制通过引入概率稀疏性,优化了自注意力过程中的计算效率,具体如图 2 所示。

Informer 模型针对电力负荷预测的时间序列分析任务,进行了三项关键优化。首先,概率稀疏自注意力机制作为模型创新的核心,通过应用如 Top-k 算法的稀疏化策略,显著减少了注意力矩阵中的非零元素数量,从而将模型的计算复杂度降至对数级别^[14-15]。这种机制不仅减少了模型参数量,而且增强了模型对长序列数据的适应性和泛化能力,有效避免了过拟合问题。其次,自注意力提炼过程通过级联多个低层次的稀疏自注意力矩阵,形成高层次的紧凑表

示,这不仅提升了模型的泛化能力,还提高了训练效率,并缓解了深层网络中的梯度消失问题。最后,生成式解码器的设计摒弃了逐步迭代预测的传统方法,改为一次性生成

目标序列,利用序列前部信息引导预测,减少了长序列预测中的累积误差,增强了预测结果的连贯性。

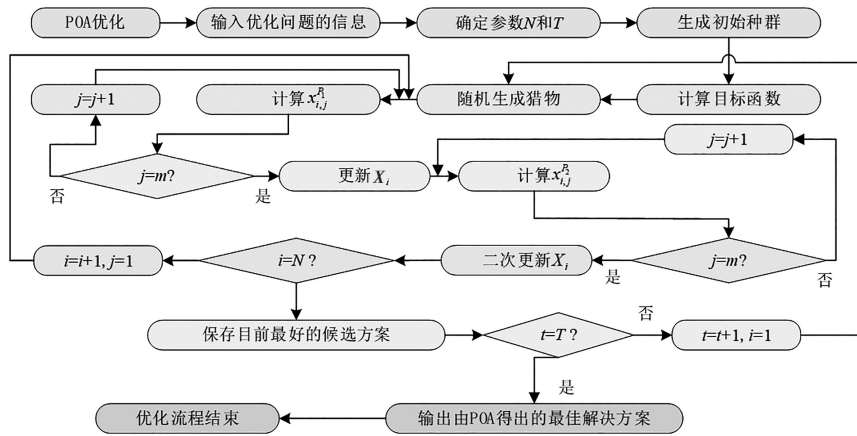


图1 POA 优化流程图

Fig. 1 Flow chart of POA optimization

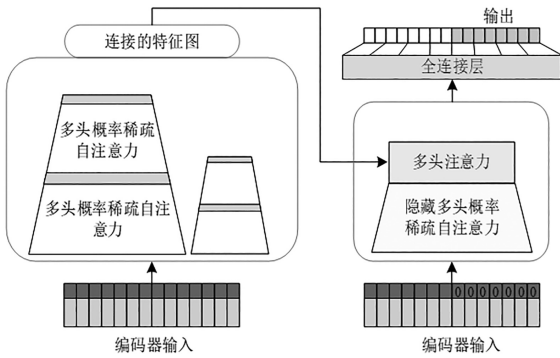


图2 Informer 算法结构

Fig. 2 Structure of Informer algorithm

时间失真指数(time distortion index, TDI)作为一种评估两个时间序列相似性的工具,它在衡量振幅特征的同

时,也特别关注了时间轴上的扭曲变形。TDI的一个优势是其对噪声和小幅时间扭曲的鲁棒性,这使得它在面对测量误差或数据丢失时依然能够保持有效性。不过,TDI在处理极端扭曲或大规模时间错位时可能不够敏感,并且在处理长序列或高维数据时,其计算成本较高。为了进一步提升电力负荷预测的准确性,特别是在城市短期电力负荷预测中,研究者们引入了一种新的损失函数——包含形状和时间失真的扭曲损失(distortion loss including shape and time, DILATE)。DILATE损失不仅考虑了预测曲线的形状失真,还考虑了时间扭曲,通过量化预测曲线与实际曲线之间的全局差异,推动模型生成更加平滑且与实际趋势相符合的预测结果。基于这一理念,研究提出了一种改进型模型IPOA-Informer-DILATE,该模型专门针对预测曲线失真、时间预测滞后、长序列预测精度不足以及模型参数调整等难题进行了优化。该模型的框架流程详见图3。

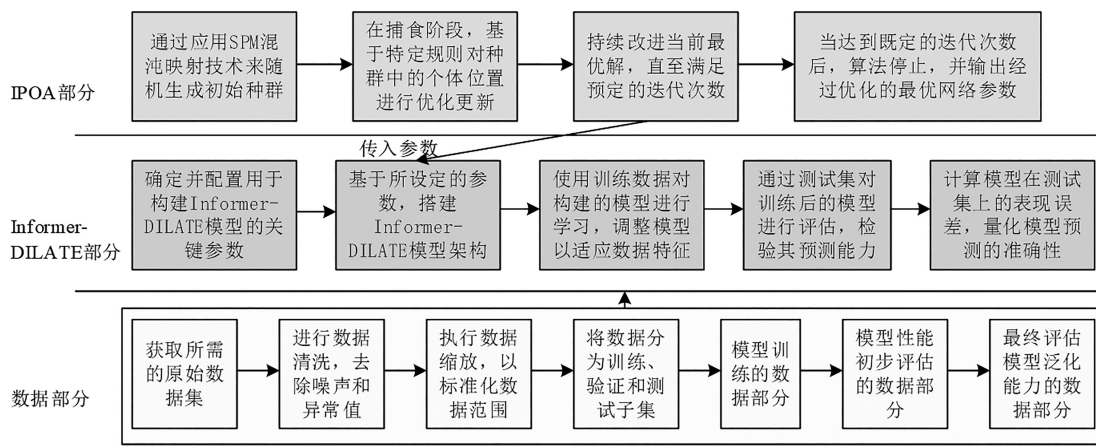


图3 IPOA-Informer-DILATE 模型的工作流程

Fig. 3 Workflow of IPOA-Informer-DILATE model

研究提出的 IPOA-Informer-DILATE 模型,首先,对收集到的原始数据执行清洗操作,去除无效或错误的记录,

并通过数据缩放技术标准化数据,以消除不同量纲的影响。随后,将数据集划分为训练集、验证集和测试集,为后

续的模型训练和评估打下基础。第二,启动 IPOA 算法,利用 SPM 混沌映射对种群进行初始化,确保初始解的多样性。初始化得到的参数将作为 Informer-DILATE 模型构建的起点。第三,利用训练集数据训练 Informer-DILATE 模型,并通过验证集评估模型性能,DILATE 损失值作为适应度指标反馈至 IPOA 算法。同时,基于测试集计算模型的预测误差,以评估模型的泛化能力。其次,IPOA 算法根据适应度反馈更新种群参数。若迭代次数未达到预设的最大值,进入探索阶段和应用 Levy 飞行策略改进的捕食阶段,进一步优化种群成员。这一过程循环进行,直至满足迭代终止条件。此外,在达到最大迭代次数后,IPOA 算法输出最优网络参数。利用这些参数配置 Informer-DILATE 模型,进行最终训练,得到预测模型。最终训练得到的模型将用于对测试集进行预测,生成电力负荷预测结果。

2 算法性能评估与误差分析

为验证提出的改进策略及其算法性能,研究进行了性能测试,将研究提出的改进的 IPOA 与 POA 算法、改进鲸鱼优化算法(improved whale optimization algorithm, IWOA)以及改进的粒子群优化算法(improved particle swarm optimization, IPSO)算法进行比较。算法的超参数通过网络搜索得到,以确保测试条件的一致性和结果的可比性。实验在标准化的测试环境中进行,确保了测试环境、迭代

次数和种群规模的一致性。测试配置包括安装有 Windows 10 Home(64 位)操作系统的工作站,配备 Intel Core i7-9700K 四核处理器,具备 3.6 GHz 的基本时钟频率,集成 NVIDIA GeForce RTX 2070 Super 图形处理单元,以及 PyCharm Community Edition 软件开发环境。单峰及多峰基准测试函数如表 1 所示。

表 1 单峰及多峰基准测试函数

测试函数	维度	定义域	最优解
$F_1(x) = \sum_{i=1}^d x_i $	30	$[-100, 100]$	0
$F_2(x) = \sum_{i=1}^d x_i + \prod_{i=1}^d x_i $	30	$[-100, 100]$	0
$F_3(x) = -\sum_{i=1}^d x_i \sin x_i + 0.1x_i $	30	$[0, 10]$	0
$F_4(x) = -\prod_{i=1}^d \sqrt{x_i} \sin x_i$	30	$[0, 10]$	0

评估智能优化算法性能需基于收敛速度、最优解质量和稳定性 3 个关键指标。收敛速度通过记录目标函数或适应度随迭代次数或时间的变化来确定,反映算法达到全局最优解的效率。最优解质量通过比较算法所得解与真实最优解之间的误差,以最小误差值或相对误差百分比衡量。稳定性则通过方差或标准差来评估算法在不同环境或参数设置下结果的可靠性。为确保评估的全面性,各算法需独立运行 30 次,每次迭代 2 000 次,以确定测试函数的最差和最优解。不同测试函数下的收敛曲线如图 4 所示。

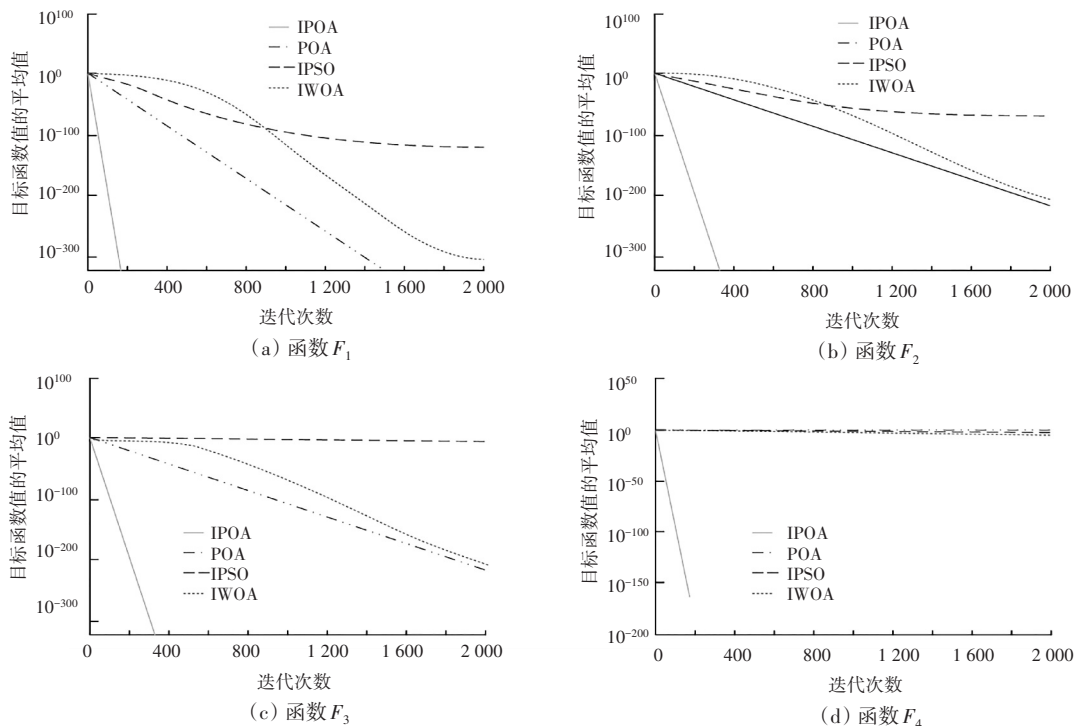


图 4 不同测试函数下的收敛曲线

Fig. 4 Convergence curves under different test functions

图 4(a)为算法在函数 F_1 下的收敛曲线,IPOA 算法的性能曲线下降最快,迅速接近最优值,而 POA 算法的性

能曲线也表现出较快的下降趋势。IPSO 和 IWOA 算法的性能曲线相对较慢地接近最优值。在迭代次数为 2 000

次时,IPOA 算法的性能似乎已经非常接近最优,而 POA 算法的性能也相当不错。图 4(b)为算法在函数 F_2 下的收敛曲线,IPOA 算法的性能曲线同样快速下降,并且在较少的迭代次数内就非常接近最优值。POA 算法的性能曲线也显示出较好的性能,但略逊于 IPOA。IPSO 和 IWOA 算法的性能曲线下降速度较慢。图 4(c)为算法在函数 F_3 下的收敛曲线,IPOA 算法的性能曲线再次显示出快速下降的趋势,并且在迭代次数增加时迅速接近最优值。POA

算法的性能曲线也快速下降,但整体性能略低于 IPOA。IPSO 和 IWOA 算法的性能曲线在初期下降较慢,但随着迭代次数的增加,逐渐接近最优值。图 4(d)为算法在函数 F_4 下的收敛曲线,IPOA 算法的性能曲线快速下降,并在较少迭代次数内非常接近最优值。POA 算法的性能曲线也显示出良好的性能,但整体上仍然低于 IPOA。IPSO 和 IWOA 算法的性能曲线在开始时下降较慢,但随着迭代次数的增加,性能有所提升。




图 5 不同模型的电力负荷误差

Fig. 5 Power load errors of different models

图 5 展示了 POA 与 IPOA-Informer-DILATE 模型在电力负荷预测误差方面的对比。分析结果表明,POA 模型在预测中表现出较大的误差波动,误差范围 $-7.5 \sim 5.8 \text{ kW} \cdot \text{h}$ 。而 IPOA-Informer-DILATE 模型则展现出较小的误差范围,介于 $-4.3 \sim 4.3 \text{ kW} \cdot \text{h}$ 之间, R^2 值提高了 $2.53\% \sim 6.6\%$,揭示了其在稳定性上的优势。改进后的 IPOA-Informer-DILATE 模型,通过结合智能优化算法与先进的时间序列技术,显著降低了预测误差,增强了模型的预测精度和稳定性。

3 结论

研究在双碳目标背景下,针对电力负荷预测的准确性和稳定性问题,提出了一种结合 Informer 算法和 IPOA 的预测模型。通过对原始数据进行清洗和标准化处理,利用 SPM 混沌映射初始化种群,并通过 IPOA 算法优化 Informer 模型的超参数,引入 TDI 和 DILATE 损失函数,显著提升了模型在长序列预测任务中的性能。实验结果显示,改进模型的预测误差范围从 $-7.5 \sim 5.8 \text{ kW} \cdot \text{h}$ 降低至 $-4.3 \sim 4.3 \text{ kW} \cdot \text{h}$, R^2 值提高 2.53% 至 6.6% ,验证了模型在提高预测精度和稳定性方面的有效性。然而,模型在极端气候条件下的适应性和泛化能力仍需进一步研究。未来工作将优化模型结构,提高其适应性,探索更高效的参数调整算法,并增强模型的可解释性,以期为电力系统提供更精确的负荷预测工具。

参考文献

[1] 宿连超,王涛,谭虎. 基于扩频通信技术的农村电力负荷自动监测方法[J]. 自动化技术与应用, 2024, 43(7):102-106.

- [2] 游兆阳,沈聪,冯晨,等. 基于 GIS 技术的电力通信光缆线路故障智能定位系统[J]. 自动化技术与应用, 2024, 43(7):121-124.
- [3] 邝柱祥. 基于区块链的电力计量系统分布式数据可信收集方法[J]. 环境技术, 2023, 41(12):106-111.
- [4] 肖威,方娜,邓心. 基于 VMD-LSTM-IPSO-GRU 的电力负荷预测[J]. 科学技术与工程, 2024, 24(16):6734-6741.
- [5] Yadav A, Bareth R, Kochar M, et al. Gaussian process regression-based load forecasting model[J]. IET Generation, Transmission & Distribution, 2024, 18(5): 899-910.
- [6] 刘杰,从兰美,夏远洋,等. 基于 DBO-VMD 和 IWOA-BiLSTM 神经网络组合模型的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(8):123-133.
- [7] 范茜茜,王国强,罗贺,等. 基于 N-BEATS 与辅助编码器的短期电力负荷预测[J]. 电网技术, 2024, 48(4):1612-1621.
- [8] 张亚超,朱蜀,林俊杰. 基于源荷储灵活资源协同的电热综合能源系统实验平台[J]. 实验室研究与探索, 2024, 43(7):69-75.
- [9] 胡欣月,黄奇峰,张理寅,等. 考虑隐私保护的综合能源负荷联合聚类方法[J]. 电工电能新技术, 2024, 43(7):60-69.
- [10] 陈胜,刘鹏飞,王平,等. 基于 LSTM 人工神经网络的电力系统负荷预测方法[J]. 沈阳工业大学学报, 2024, 46(1):66-71.
- [11] 白星振,赵康,葛磊蛟,等. 基于 EWT-GRU-RR 的配电网短期电力负荷预测模型[J]. 山东科技大学学报(自然科学版), 2023, 42(5):77-87.
- [12] 李文英,杨高才,文明,等. 基于时空图注意力的短期电力负荷预测方法[J]. 湖南大学学报(自然科学版), 2024, 51(2): 57-67.
- [13] 孙静,彭勇刚,倪旖旎,等. 基于改进联邦学习算法的电力负荷预测方法[J]. 高电压技术, 2024, 50(7):3039-3049.
- [14] 冉秀敏,韩玺江,窦桑,等. 基于变分模态分解联合注意力机制的电力负荷预测[J]. 自动化技术与应用, 2025, 44(11):57-60.
- [15] 申洪涛,李飞,史轮,等. 基于气象数据降维与混合深度学习的短期电力负荷预测[J]. 电力建设, 2024, 45(1):13-21.
- [16] 林彦旭,高辉. 基于 SSA-VMD-BiLSTM 模型的充电站负荷预测方法[J]. 广东电力, 2024, 37(6):53-61.